



①9 BUNDESREPUBLIK
DEUTSCHLAND



DEUTSCHES
PATENTAMT

⑫ Off nlegungsschrift
⑩ DE 196 24 301 A 1

⑤1 Int. Cl. 6:
G 05 B 13/02
G 05 B 19/05
G 06 F 15/18
// B21B 37/00

②1 Aktenzeichen: 196 24 301.7
②2 Anmeldetag: 18. 6. 96
④3 Offenlegungstag: 8. 1. 98

DE 196 24 301 A 1

⑦1 Anmelder:
Siemens AG, 80333 München, DE


⑦2 Erfinder:
Broese, Einar, Dr.rer.nat., 91058 Erlangen, DE;
Gramckow, Otto, Dr.-Ing., 91052 Erlangen, DE;
Malisch, Frank-Oliver, Dipl.-Inform., 85579
Neubiberg, DE; Schlang, Martin, Dr.-Ing., 81735
München, DE

⑤6 Entgegenhaltungen:
DE 44 18 364 A1
US 53 96 415 A
EP 06 09 999 A1
Automatica, Bd. 28, Nr. 6, S. 1083-1084, 1992;

Prüfungsantrag gem. § 44 PatG ist gestellt

⑤4 Lernverfahren für ein neuronales Netz

⑤7 Die Erfindung betrifft ein Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das neuronale Netz in zumindest zwei Ausführungen, einem Regel- bzw. Steuernetz, mit dem der Prozeß gesteuert bzw. geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet, und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet, ausgeführt wird, wobei das Regel- bzw. Steuernetz nach Ablauf einer bestimmten Lernzeit für das Hintergrundnetz oder aufgrund eines externen Ereignisses durch das Hintergrundnetz ersetzt wird.



DE 196 24 301 A 1

Die Erfindung betrifft ein Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines insbesondere industriellen Prozesses mit sich zeitlich verändernden Parametern.

Neuronale Netze müssen, bevor sie ihre Generalisierungsfähigkeit erhalten, zunächst mit Lern- oder Trainingsdaten trainiert werden. Das Sammeln dieser Trainingsdaten ist oft langwierig und mit hohem Aufwand verbunden.

Ein Beispiel hierfür ist das aus der DE-OS 44 16 364 bekannte neuronale Netz, das aus einer Vielzahl von ihm zugeführten vorausberechneten Eingangsgrößen als Netzwerkantwort einen Prozeßparameter berechnet, der zur Voreinstellung eines Systems zur Regelung eines technischen Prozesses dient. So wird z. B. bei einem Walzprozeß ein Vorhersagewert für die Walzkraft in Abhängigkeit von der Walzguttemperatur, der Dickenabnahme und anderen material- und anlagenspezifischen Eingangsgrößen berechnet. Der von dem neuronalen Netz nachgebildete Zusammenhang zwischen der Walzkraft und den Eingangsgrößen wird on-line nach jedem Prozeßablauf, also nach jedem Walzgutdurchlauf, an das reale Prozeßgeschehen angepaßt. Dazu werden die während des Prozeßablaufs gemessenen und anschließend nachberechneten Eingangsgrößen und die Walzkraft in einem Datenpunkt zusammengefaßt, der dann zur Adaption von Parametern des neuronalen Netzes herangezogen wird. Die Adaption erfolgt mit jedem neu ermittelten Datenpunkt, also online. Die Adaption muß sich durch eine besondere Stabilität auszeichnen, da sie häufig direkt und ohne Überwachung durch einen Fachmann auf der prozeßausführenden Anlage durchgeführt wird. Daher werden beim on-line Training nur unkritische Parameter des neuronalen Netzes adaptiert, wobei Adoptionsalgorithmen und Netzwerkstrukturen verwendet werden, die eine Stabilität des Verfahrens gewährleisten; z. B. Minimierung der quadratischen Fehlerfunktion zwischen der Netzwerkantwort und der nachberechneten Walzkraft, wobei die Fehlerfunktion vorzugsweise nur ein globales Minimum, aber keine lokalen Minima aufweist.

Damit das bekannte neuronale Netz bereits zu Beginn des online-Trainings zumindest annähernd sinnvolle Walzkraftwerte vorhersagt, kann es anhand eines die Walzkraft in Abhängigkeit von zufällig vorgegebenen Eingangsgrößen berechnenden Walzkraftmodells vortrainiert werden. Steht ein derartiges Modell nicht zur Verfügung, so kann das für das Vortraining nötige Vorwissen durch das Sammeln von Trainingsdaten beispielsweise auf vergleichbaren Anlagen erworben und in das neuronale Netz eingebracht werden.

Der Erfindung liegt die Aufgabe zugrunde, einen Prozeß mit sich zeitlich verändernden Parametern in bezug auf die Qualität hochwertig zu steuern und zu regeln. Dabei ist es insbesondere bei der Neuinbetriebnahme einer Anlage oder wesentlichen Veränderungen einer bestehenden Anlage, die mit neuronalen Netzen gesteuert wird, wünschenswert, das neuronale Netz in die Lage zu versetzen, ohne Vortraining direkt auf der Anlage bereits nach wenigen Datenpunkten ein sinnvolles Verhalten zu zeigen. Das gleiche gilt beim Umrüsten einer bestehenden Anlage, wenn auf eine vorherige Sammlung von Daten verzichtet werden soll. Ferner sollen Langzeitsdriften der Anlage erkannt und kompensiert werden.

Die Aufgabe wird erfindungsgemäß durch ein Lern-

verfahren für ein neuronales Netz zum Regeln oder Steuern eines insbesondere industriellen Prozesses mit sich zeitlich verändernden Parametern gelöst, wobei das neuronale Netz in zumindest zwei Ausführungen, einem Regel- bzw. Steuernetz, mit dem der Prozeß gesteuert und geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet, und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet, ausgeführt wird, wobei das Regel- bzw. Steuernetz nach Ablauf einer bestimmten Lernzeit für das Hintergrundnetz oder aufgrund eines externen Ereignisses durch das Hintergrundnetz ersetzt wird.

Eine weitere Lösung stellt ein Lernverfahren dar, bei dem das Lernen während des Prozeßablaufs in zwei Lernphasen unterteilt ist, eine Initiallernphase und eine Betriebslernphase, wobei die Menge der Trainingsdaten, mit denen das neuronale Netz trainiert wird, in der Initiallernphase wächst und die Menge der Trainingsdaten in der Betriebslernphase weitgehend konstant bleibt.

Die Aufgabe wird weiterhin durch das in Patentanspruch 3 angehende Lernverfahren gelöst.

Besonders vorteilhafte Lösung der Aufgabe stellen die in den Patentansprüchen 4 bis 7 angegebenen Lernverfahren dar.

Weitere Vorteile und erfindungsgemäße Einzelheiten ergeben sich aus der nachfolgenden Beschreibung von Ausführungsbeispielen, anhand der Zeichnungen und in Verbindung mit den Unteransprüchen. Im einzelnen zeigen:

Fig. 1 einen Trainingsablauf eines neuronalen Netzes

Fig. 2 verschiedene Lernphasen eines neuronalen Netzes

Fig. 3 und 4 Beispiele für die bei der zyklisch wiederholten Adaption verwendete Trainingsdatenmenge,

Fig. 5 ein Beispiel für die Trainingsdatenmenge beim Lernen mit exponentiellem Vergessen und

Fig. 6 ein Beispiel für den typischen Fehlverlauf bei dem erfindungsgemäßen Lernverfahren im Vergleich zu einem Referenz-Lernverfahren,

Fig. 7 ein adaptiv angepaßtes neuronales Netz.

Fig. 1 zeigt den Trainingsablauf eines neuronalen Netzes für die Steuerung und Regelung eines Prozesses bzw. einer Anlage. Das entsprechende neuronale Netz ist in zumindest zwei Ausführungen ausgeführt, einem Regel- bzw. Steuernetz, mit dem der Prozeß gesteuert und geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet, und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet. Das Regel- bzw. Steuernetz befindet sich in einem Zustand 5, in dem es den Prozeßablauf regelt bzw. steuert. Gleichzeitig befindet sich das Hintergrundnetz im Training 1. Beim Abschluß 2 des Trainings 1 des Hintergrundnetzes wird es einer Plausibilitätskontrolle 3 unterzogen. Bei einer positiven Plausibilitätskontrolle wird das Regel- und Steuernetz durch das plausible Hintergrundnetz ersetzt. Während das alte Hintergrundnetz als neues Regel- bzw. Steuernetz den Prozeßablauf regelt oder steuert, wird durch weiteres Training 1 ein neues Hintergrundnetz erzeugt. Das Training eines Hintergrundnetzes kann ständig oder zeitweise erfolgen, wenn ein neues Regel- bzw. Steuernetz benötigt wird. Anstoß für ein

neues Hintergrundtraining kann das Verstreichen einer definierten Zeit oder ein externes Ereignis, wie z. B. das Walzen eines Walzbandes aus neuem Material sein. Ausgangsbasis für ein neues Hintergrundnetz kann ein untrainiertes Rohnetz, ein Regel- bzw. Steuernetz oder ein altes Hintergrundnetz sein.

Fig. 2 zeigt drei verschiedene Trainingsphasen in Bezug auf das erfindungsgemäße Lernverfahren für ein neuronales Netz. Die einzelnen Phasen sind eine Vorbetriebslernphase 7, eine Initiallernphase 8 und eine Betriebslernphase 9. In der Vorbetriebslernphase wird das neuronale Netz, das zur Regelung bzw. Steuerung eines vorteilhafterweise industriellen Prozesses eingesetzt werden soll, vorab trainiert. In der Vorbetriebslernphase 7 ist es möglich, durch entsprechende Daten aus anderen, bereits in Betrieb befindlichen Anlagen die Erfahrungen, die in diesen Anlagen gesammelt wurden, zu berücksichtigen. Auf die Vorbetriebslernphase 7 kann jedoch beim erfindungsgemäßen Lernverfahren verzichtet werden. In diesem Fall reicht das durch Datensammlung an der aktuellen Anlage akkumulierte Wissen zum Training des neuronalen Netzes aus. Der Vorbetriebslernphase folgen zwei weitere Lernphasen, die Initiallernphase 8 und die Betriebslernphase 9, die während des Prozeßablaufs erfolgen. Wird auf die Vorbetriebslernphase 7 verzichtet, so existieren nur die beiden Lernphasen Initiallernphase 8 und Betriebslernphase 9. Die Initiallernphase 8 ist dadurch gekennzeichnet, daß die Datenbasis der Trainingsdaten anwächst, während die Datenmenge zum Training des neuronalen Netzes in der Betriebslernphase 9 weitgehend konstant bleibt. Im vorliegenden Ausführungsbeispiel wächst in der Initiallernphase 8 nicht nur die zum Training verwendete Datenbasis, sondern auch das trainierte neuronale Netz selbst. Das heißt, die Anzahl der Knoten in den verdeckten Ebenen bzw. der verdeckten Ebene vergrößert sich.

Diese beiden unterschiedlichen Lernphasen während des Betriebs, die Initial- und die Betriebslernphase, sind in Fig. 3 verdeutlicht, in der die Anzahl der zum zyklischen Training des neuronalen Netzes 1 verwendeten Datenpunkte in Abhängigkeit von dem Beitrag dieser Datenpunkte zum Training aufgetragen sind. Während der Initiallernphase 7 erfolgt das zyklisch wiederholte Training mit einer stetig wachsenden Trainingsdatenmenge 15, wobei jedesmal alle von Beginn des Lernverfahrens an gespeicherten Datenpunkte verwendet werden. Die Häufigkeit des zyklisch wiederholten Trainings ist ein für die vorgegebene Anwendung zu optimierender Parameter, wobei z. B. nach jedem neuen Datenpunkt, nach einem vorgegebenen prozentualen Anwachsen der Trainingsdatenmenge oder, wenn die Abweichung zwischen den Ausgangsgrößen des neuronalen Netzes und ihren richtigen Werten einen bestimmten Wert übersteigt, eine erneute Adaption erfolgt. Darüberhinaus läßt sich die Größe des neuronalen Netzes in Abhängigkeit von der Größe der vorliegenden Trainingsdatenmenge verändern, wobei mit einem kleinen neuronalen Netz begonnen wird, das im Laufe der Zeit langsam vergrößert wird. Die Festlegung der Netzgröße erfolgt z. B. durch Methoden der "Cross-Validation" oder andere Heuristiken, wie Residualfehler im Eingangsraum.

Nach einer vorgegebenen Zeit oder, wenn die Trainingsdatenmenge einen vorgegebenen Wert NF erreicht, beginnt die Betriebslernphase, in der die Trainingsdatenmenge 10 konstant gehalten wird. Die Größe NF kann statisch sein oder dynamisch beispielsweise

durch Techniken der Cross-Validation festgelegt werden. Die Häufigkeit der zyklisch erfolgenden Adaption sowie die Größe des neuronalen Netzes 1 ist entweder konstant oder wird auf ähnliche Weise bestimmt, wie in der Initiallernphase.

Zu Beginn der Inbetriebnahme einer neuronal gesteuerten Anlage werden in der Regel noch sehr viele Anlagenparameter verändert, um die Anlage zu optimieren. Das suboptimale Verhalten direkt nach der Inbetriebnahme sollte aber von dem neuronalen Netz 1 möglichst wieder vergessen werden. Deshalb ist entsprechend der Darstellung in Fig. 4 vorgesehen, die in der Initiallernphase 7 ständig wachsende Trainingsdatenmenge 11 nicht komplett zu verwenden, sondern die ältesten Datenpunkte sukzessive zu vergessen. Das Wachstum der Trainingsdatenmenge 11 hat dabei natürlich schneller zu erfolgen als das Vergessen. Die Geschwindigkeit des Vergessens kann in Form eines konstanten Bruchteils der Wachstumsrate der Trainingsdatenmenge 11, in Abhängigkeit von der Abweichung zwischen den Ausgangsgrößen des neuronalen Netzes und ihren richtigen Werten oder in Abhängigkeit von dem Expertenwissen des Inbetriebnehmers festgelegt werden.

Fig. 5 zeigt ein Beispiel für eine exponentiell abfallende "natürliche" Vergessensfunktion einer Trainingsdatenmenge 12, die dadurch zustande kommt, daß die Datenpunkte in der Trainingsdatenmenge 12 mit zunehmendem Alter mit einem immer geringeren Gewichtungsfaktor gewichtet werden.

In Fig. 6 ist für das erfindungsgemäße Lernverfahren der typische Fehlerverlauf 13 des Residualfehlers F des neuronalen Netzes 1 in Abhängigkeit von der Anzahl der zur Verfügung stehenden Datenpunkte N im Vergleich zu dem Fehlerverlauf 14 eines Referenz-Lernverfahrens, hier Vererbungsdatei mit analytischem Modell im eingeschwungenen Zustand, aufgezeigt.

Fig. 7 zeigt ein neuronales Netz 16, dem eine Mehrzahl von in einem Eingangsvektor x zusammengefaßten Eingangsgrößen zugeführt wird und das in Abhängigkeit davon eine, gegebenenfalls ebenfalls mehrdimensionale, Antwort y_{NN} erzeugt. Die Antwort y_{NN} ist von einstellbaren Parametern p_1 und/oder p_2 des neuronalen Netzes 16 abhängig. Das neuronale Netz 16 dient bei dem gezeigten Ausführungsbeispiel dazu, den Zusammenhang zwischen Einflußgrößen eines technischen Prozesses, die durch den Eingangsvektor x repräsentiert werden, und einem Prozeßparameter y , repräsentiert durch die Antwort y_{NN} , nachzubilden. Ein Beispiel hierfür ist die Vorhersage der Walzkraft in einem Walzprozeß in Abhängigkeit von material- und anlagenspezifischen Einflußgrößen, wie unter anderem der Walzguttemperatur, der Walzgutfestigkeit, der Walzgutdicke und der Dickenabnahme.

Um den nachzubildenden Zusammenhang zu lernen, und das neuronale Netz 16 an das tatsächliche Prozeßgeschehen anzupassen, werden die Parameter p_1 und/oder p_2 des neuronalen Netzes 16 mit Hilfe von Adaptionsalgorithmen 17 und 18 im Sinne einer Verringerung des Fehlers zwischen der von dem neuronalen Netz 16 gelieferten Antwort y_{NN} und dem tatsächlichen Wert des Prozeßparameters y verändert.

Dabei erfolgt nach jedem n -ten ($n \geq 1$) Prozeßablauf, also nach jedem Walzgutdurchlauf, mittels des Adaptionsalgorithmus 17 eine on-line-Adaption, indem die während des erfolgten aktuellen Prozeßablaufs gemessenen und nachberechneten Einflußgrößen X_{nach} dem neuronalen Netz 16 aufgegeben werden und die daraus resultierende Antwort y_{NN} mit dem ebenfalls gemessenen

nen oder nachberechneten Prozeßparameter y verglichen wird. Nicht plausible Werte oder Meßfehler werden durch die Nachberechnung ausgeschieden. In Abhängigkeit von dem dabei ermittelten Fehler $y - y_{NN}$ werden ausgewählte Parameter p_1 des neuronalen Netzes 16 im Sinne einer Fehlerverringerung verändert. Dabei werden unkritische Parameter p_1 und solche Adaptionen algorithmen gewählt, die eine Stabilität der on-line-Adaption gewährleisten und es erlauben, schnellen Prozeßzustandsänderungen zu folgen.

Die nach jedem n -ten Walzgutdurchlauf ermittelten Eingangsgrößen des Eingangsvektors x bilden zusammen mit dem gemessenen bzw. nachberechneten Prozeßparameter y , der als Bezugsgröße für den Vergleich mit der Antwort y_{NN} dient, einen Datenpunkt, der in einer Speichereinrichtung 19 gespeichert wird. Auf der Grundlage einer aus mehreren gespeicherten Datenpunkten, gegebenenfalls durch Clustern, Selektieren oder Mitteln gebildeten Trainingsdatenmenge wird in zyklischen Abständen ein Training des neuronalen Netzes 16 vorgenommen, wobei die Parameter p_1 und p_2 des neuronalen Netzes 16 mittels des Adaptionalgorithmus 8 adaptiv verändert werden. Die Parameter p_1 und p_2 können dieselben oder teilweise oder ganz unterschiedlich sein. Wird das zyklisch wiederholte Training als Hintergrund-Training durchgeführt, kann auf der Basis beliebig großer Trainingsdatenmengen und mit zeitaufwendigen global optimierenden Lernalgorithmen gearbeitet werden.

Nach Abschluß eines Hintergrundtrainings wird das neuronale Netz 16 zuerst einer on-line Adaption mit zumindest einem Teil der der Trainingsdatenmenge zugrundeliegenden Datenpunkte unterzogen, bevor das neuronale Netz 16 wieder für die Steuerung der Anlage aktiviert wird und mit neuen Datenpunkten on-line weitertrainiert wird. So wird sichergestellt, daß sich das neuronale Netz nach dem globalen Hintergrundtraining sofort wieder an die aktuelle Tagesform der zu steuernden Anlage anpaßt.

Patentansprüche

1. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das neuronale Netz in zumindest zwei Ausführungen, einem Regel- bzw. Steuernetz, mit dem der Prozeß gesteuert bzw. geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet, und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet, ausgeführt wird, wobei das Regel- bzw. Steuernetz nach Ablauf einer bestimmten Lernzeit für das Hintergrundnetz oder aufgrund eines externen Ereignisses durch das Hintergrundnetz ersetzt wird.
2. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das Lernen während des Prozeßablaufs in zwei Lernphasen unterteilt, einer Initiallernphase und einer Betriebslernphase, erfolgt, wobei die Menge der Trainingsdaten, mit denen das neuronale Netz trainiert wird, in der Initiallernphase wächst und die Anzahl der Trainingsdaten in der Betriebslernphase weitgehend konstant bleibt.

3. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei sich die Menge der Trainingsdaten, mit denen das neuronale Netz trainiert wird, ändert, und wobei die Größe des neuronalen Netzes an die Menge der Trainingsdaten angepaßt wird.

4. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das neuronale Netz in zumindest zwei Ausführungen, einem Regel- bzw. Steuernetz mit dem Prozeß gesteuert und geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet, ausgeführt wird, wobei das Regel- bzw. Steuernetz nach Ablauf einer bestimmten Lernzeit für das Hintergrundnetz oder aufgrund eines externen Ereignisses durch das Hintergrundnetz ersetzt wird, wobei das Trainieren des Regel- bzw. Steuernetzes während des Prozeßablaufs in zwei Lernphasen unterteilt, einer Initiallernphase und einer Betriebslernphase, erfolgt, wobei die Menge der Trainingsdaten, mit denen das Hintergrundnetz trainiert wird, in der Initiallernphase wächst und die Menge der Trainingsdaten in der Betriebslernphase weitgehend konstant bleibt.

5. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das neuronale Netz in zumindest zwei Ausführungen, einem Regel- bzw. Steuernetz mit dem Prozeß gesteuert und geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet, ausgeführt wird, wobei das Regel- bzw. Steuernetz nach Ablauf einer bestimmten Lernzeit für das Hintergrundnetz oder aufgrund eines externen Ereignisses durch das Hintergrundnetz ersetzt wird und wobei sich die Menge der Trainingsdaten, mit denen das Hintergrundnetz trainiert wird, ändert und die Größe des Hintergrundnetzes an die Menge der Trainingsdaten angepaßt wird.

6. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das Lernen während des Prozeßablaufs in zwei Lernphasen unterteilt, einer Initiallernphase und einer Betriebslernphase, erfolgt, wobei die Menge der Trainingsdaten, mit denen das neuronale Netz trainiert wird, in der Initiallernphase wächst und die Menge der Trainingsdaten in der Betriebslernphase weitgehend konstant und wobei das neuronale Netz in der Initiallernphase mit der Zunahme der Trainingsdaten wächst.

7. Lernverfahren für ein neuronales Netz zum Regeln oder Steuern eines, insbesondere industriellen, Prozesses mit sich zeitlich verändernden Parametern, wobei das neuronale Netz in zumindest zwei Ausführungen, einem Regel- bzw. Steuernetz mit

dem Prozeß gesteuert und geregelt wird und das mit aktuellen Prozeßdaten derart trainiert wird, daß es ein Abbild des aktuellen Prozesses bildet, und einem Hintergrundnetz, das während des Betriebes mit repräsentativen Prozeßdaten derart 5 trainiert wird, daß es ein Abbild des Prozesses über einen längeren Zeitraum gemittelt bildet, ausgeführt wird, wobei das Regel- bzw. Steuernetz nach Ablauf einer bestimmten Lernzeit für das Hintergrundnetz oder aufgrund eines externen Ereignisses durch das Hintergrundnetz ersetzt wird das Training des Regel- bzw. Steuernetzes während des Prozeßablaufs in zwei Lernphasen unterteilt, einer Initiallernphase und einer Betriebslernphase, erfolgt, wobei die Menge der Trainingsdaten, mit denen das Regel- bzw. Steuernetz trainiert wird, in der Betriebslernphase weitgehend konstant bleibt und in der Initiallernphase zunimmt und wobei das Hintergrundnetz in der Initiallernphase mit der Zunahme der Trainingsdaten wächst. 10 15 20

8. Verfahren nach Anspruch 1, 4, 5 oder 7, dadurch gekennzeichnet, daß sich die Lernzeit für das Hintergrundnetz nach den Zeitkonstanten der Parameterveränderungen des Prozesses richtet.

9. Verfahren nach Anspruch 1, 4, 5, 7 oder 8, dadurch gekennzeichnet, daß mehrere Hintergrundnetze gleichzeitig, aber zeitlich versetzt, trainiert werden. 25

10. Verfahren nach Anspruch 1, 4, 5, 7, 8 oder 9, dadurch gekennzeichnet, daß ein Hintergrundnetz vor Übernahme von Steuer- und Regelungsaufgaben auf Plausibilität z. B. durch Durchlaufen eines speziellen Testdatensatzes oder durch parallelen Einsatz mit dem Regel- bzw. Steuernetz überprüft wird, wobei die Ausgänge der beiden Netze verglichen werden und einen bestimmten Toleranzwert nicht überschreiten dürfen. 30 35

11. Verfahren nach Anspruch 1, 4, 5, 7, 8, 9 oder 10, dadurch gekennzeichnet, daß das Hintergrundnetz vor einem Ersetzen des Regel- bzw. Steuernetzes durch das Hintergrundnetz einem kurzen Training mit aktuellen Prozeßdaten unterzogen wird, so daß es an die aktuelle Tagesform der zu steuernden Anlage angepaßt ist. 40

12. Verfahren nach Anspruch 3, 5, 6, 7, 8, 9, 10 oder 11, dadurch gekennzeichnet, daß das Wachstum eines neuronalen Netzes in der Lernphase durch Einfügen von einzelnen Zusatzknoten und Entfernen von Knoten mit sehr geringem Gewicht erfolgt. 45

13. Einrichtung zur Durchführung des Verfahrens nach einem oder mehreren der Ansprüche 1 bis 12, dadurch gekennzeichnet, daß sie eine ProzeßBrecheneinheit aufweist. 50

14. Einrichtung nach Anspruch 13, dadurch gekennzeichnet, daß die ProzeßBrecheneinheit als Einchiprechner, z. B. als Mikrocontroller oder als Mehrchiprechner, insbesondere als ein Einplatinenrechner oder als ein Automatisierungsgerät, ausgebildet ist. 55

15. Einrichtung nach Anspruch 14, dadurch gekennzeichnet, daß das Automatisierungsgerät als speicherprogrammierbare Steuerung, als VME-Bussystem oder als Industrie-PC ausgebildet ist. 60

- Leerseite -




FIG 1




FIG 2




FIG 7

